

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky  
a komunikačních technologií

BAKALÁŘSKÁ PRÁCE



# VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

## FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

## ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

## KOREGISTRACE DKI MRI DAT S VYSOKOU MÍROU DIFUZNÍHO VÁŽENÍ

COREGISTRATION OF DKI MRI DATA WITH HIGH B-VALUES

### BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

### AUTOR PRÁCE

AUTHOR

Ladislav Krejčí

### VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Lubomír Vojtíšek, Ph.D.

BRNO 2021

# Bakalářská práce

bakalářský studijní program **Biomedicínská technika a bioinformatika**

Ústav biomedicínského inženýrství

**Student:** Ladislav Krejčí

**ID:** 165529

**Ročník:** 3

**Akademický rok:** 2020/21

## NÁZEV TÉMATU:

### Koregistrace DKI MRI dat s vysokou mírou difuzního vážení

#### POKYNY PRO VYPRACOVÁNÍ:

1) Proveďte literární rešerši týkající se předzpracování DKI (diffusion kurtosis imaging) MRI dat, se zaměřením na možnosti koregistrace obrazů s různým kontrastem. 2) Proveďte rešerši existujících softwarových nástrojů. 3) Navrhněte metodiku hodnocení funkčnosti koregistračních algoritmů. 4) Na zadaných datech ověřte funkčnost vybraných nástrojů. Zpracujte dokumentaci, včetně pracovních postupů. 5) Zhodnoťte a diskutujte výsledky.

#### DOPORUČENÁ LITERATURA:

[1] Johansen-Berg H, Behrens TEJ. Diffusion MRI From Quantitative Measurement to In-Vivo Neuroanatomy.; 2014.

[2] Nilsson M, Szczepankiewicz F, Van Westen D, Hansson O. Extrapolation-based references improve motion and eddy-current correction of high B-value DWI data: Application in Parkinson's disease dementia. PLoS One. 2015;10(11):1-22.

**Termín zadání:** 8.2.2021

**Termín odevzdání:** 28.5.2021

**Vedoucí práce:** Ing. Lubomír Vojtíšek, Ph.D.

**doc. Ing. Jana Kolářová, Ph.D.**  
předseda rady studijního programu

#### UPOZORNĚNÍ:

Autor bakalářské práce nesmí při vytváření bakalářské práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

## ABSTRAKT

Tato bakalářská práce se zabývá předzpracováním difúzně vážených MRI obrazů jejímž základem je koregistrace obrazů s různým kontrastem. Na začátku jsou uvedeny základní vlastnosti difúzních dat. V dalších kapitolách je zaměřena na metody, které odstraňují artefakty a geometrické nepřesnosti. Těmito metodami jsou převzorkování, vyhlazování, transformace a optimalizace. V práci je dále popsán software pracující s difúzními daty. V další části se věnuje kvantitativním a kvalitativním metodám srovnávající úspěšnost registrací. V praktické části jsou popsány jednotlivé postupy pro koregistraci. V závěru práce, který se zabývá kvantitativním a kvalitativním hodnocením koregistrace mezi difúzními daty, je navržen postup pro kvantitativní hodnocení registrace obrazů s uplatněním pro různé metody koregistrací nebo pro různá nastavení parametrů registrační metody.

## KLÍČOVÁ SLOVA

Magnetická rezonance (MRI), DKI data, DTI data, CHARMED, b-hodnota, koregistrace, voxely, zpracování obrazů, metody registrace, registrační nástroje

## ABSTRACT

This bachelor's thesis deals with the preprocessing of diffusion weighted MRI images based on coregistration of images with different contrast. Basic properties of diffusion data are presented in the beginning. In the following chapters it is focused on methods, which are removing motion distortion and geometrical inaccuracies. These methods are oversampling, transformation, smoothing and optimization. Software that works with diffusion data is also covered in this thesis. Another part discusses quantitative and qualitative methods that compare the success of registrations. In the practical, the different procedures for coregistration are described. Qualitative assessment of the registration quality is shown in figures and a procedure for quantitative evaluation of image registration is proposed.

## KEYWORDS

Magnetic resonance (MRI), DKI data, DTI data, CHARMED b-value, coregistration, voxels, image processing, registration methods, registration software

KREJČÍ, Ladislav. *Koregistrace DKI MRI dat s vysokou mírou difuzního vážení*. Brno, 2019, 45 s. Bakalářská práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedoucí práce: Ing. Lubomír Vojtíšek, CSc.

## PROHLÁŠENÍ

Prohlašuji, že svou bakalářskou práci na téma „Koregistrace DKI MRI dat s vysokou mírou difuzního vážení“ jsem vypracoval samostatně pod vedením vedoucího bakalářské práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené bakalářské práce dále prohlašuji, že v souvislosti s vytvořením této bakalářské práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a/nebo majetkových a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

Brno .....

.....

podpis autora

## PODĚKOVÁNÍ

Rád bych poděkoval vedoucí bakalářské práce panu Ing. Lubomíru Vojtíškovi Ph.D. za odborné vedení, konzultace, trpělivost a podnětné návrhy k práci.

Brno .....

.....

podpis autora

# Obsah

Úvod	9
<b>1 DWI data a jejich předzpracování</b>	<b>11</b>
1.1 Difúzní vážení a b-hodnota	11
1.1.1 Frakční anizotropie	13
1.1.2 CHARMED model	14
1.2 Artefakty v difúzních obrazech	15
1.2.1 Vířivé proudy (eddy currents)	15
1.2.2 Susceptibilní artefakty	16
1.3 Převzorkování obrazu	16
1.3.1 Metoda nejbližšího souseda	16
1.3.2 Metoda trilineární interpolace	16
1.3.3 B-spline interpolace	17
1.4 Vyhlazování	18
1.5 Afíní transformace	19
1.5.1 Rigidní transformace	20
1.6 Optimalizace	21
1.6.1 Kriteriaální funkce	21
1.6.2 Genetické algoritmy	22
1.6.3 Metoda roje částic	23
1.7 Registrace obrazů	23
<b>2 Softwarové nástroje</b>	<b>24</b>
2.1 AFNI	24
2.2 SPM	24
2.3 FSL	25
2.4 Elastix	25
2.5 ITK	25
2.6 MATLAB	26
2.7 3D Slicer	26
<b>3 Metody hodnocení registrace</b>	<b>27</b>
3.1 Koregistrace FA obrazů	27
3.2 Vizuální kontrola	27
3.3 Histogram	27
3.4 Joint histogram	28
3.5 Šachovnice	28

<b>4</b>	<b>Ověření funkčnosti daných nástrojů a pracovní postup</b>	<b>30</b>
4.1	Použitá data . . . . .	30
4.2	Kontrola dat . . . . .	31
4.3	Registrace pomocí FSL . . . . .	31
4.4	CHARMED registrace v matlabu . . . . .	32
4.5	FA koregistrace . . . . .	32
<b>5</b>	<b>Zhodnocení výsledků a diskuze</b>	<b>34</b>
5.1	Vyhodnocení FA koregistrace . . . . .	34
5.2	Porovnání intenzit . . . . .	35
5.3	Vyhodnocení podle šachovnice . . . . .	37
<b>6</b>	<b>Závěr</b>	<b>38</b>
	<b>Literatura</b>	<b>39</b>
	<b>Seznam symbolů, veličin a zkratk</b>	<b>43</b>
	<b>Seznam příloh</b>	<b>44</b>
<b>A</b>	<b>Elastix parametry</b>	<b>45</b>



# Seznam obrázků

1.1	B-hodnota . . . . .	12
1.2	Kurtosis . . . . .	13
1.3	Porovnání DTI a DKI . . . . .	13
1.4	Izotropie . . . . .	14
1.5	CHARMED . . . . .	15
1.6	Interpolace . . . . .	17
1.7	Gaussův filtr . . . . .	19
1.8	Konvoluce . . . . .	19
1.9	Afinní transformace . . . . .	20
1.10	Genetický algoritmus . . . . .	22
3.1	Histogram . . . . .	28
3.2	Joint histogram . . . . .	28
3.3	Šachovnice . . . . .	29
4.1	Použitá data s jejich b-hodnotami . . . . .	30
4.2	Diagram . . . . .	33
5.1	FA obrazy . . . . .	35
5.2	Porovnání intenzit . . . . .	36
5.3	Šachovnice difúzních obrazů . . . . .	37

# Úvod

Tato práce se zabývá předzpracováním difúzně vážených MRI obrazů, jejímž základem je koregistrace obrazů s různým kontrastem.

Magnetická rezonance je v dnešní době nejvyspělejší medicínskou zobrazovací technologií. Díky neustálému vývoji lze dnes pomocí MRI zobrazit jakýkoliv typ tkáně v lidském těle vysokým rozlišením a různými kontrasty mezi tkáněmi, aniž by bylo nutné invazivního zákroku. Zároveň MRI pacient nedostává žádnou dávku radiace. [4]

Pacient je vystaven pouze působení statického magnetického pole a elektromagnetických polí nižších frekvencí (Několik desítek Hz a v případě 3T cca 120MHz). Při dodržení všech bezpečnostních opatření, nebyly pozorovány žádné dlouhodobé negativní účinky těchto polí. Jediným nepříjemným aspektem MRI může být klaustrofobické prostředí tunelu a doba trvání, která se může pohybovat v řádu desítek minut. Často tedy dochází k tomu, že se pacient během snímání pohne a naruší tak kvalitu výsledného obrazu. V případě pozdějšího zpracování dat mimo samotný scanner je často potřeba data zkoregistrovat, ať už např. při normalizaci pro statistické vyhodnocení, jednotlivé objemy pro analýzu funkčních vyšetření, či právě pro výpočet difúzních parametrů. Pro některé aplikace je potřeba koregistrovat obrazy z různých modalit MRI, CT, PET atd. Mnohdy je potřeba provést další dodatečné korekce, které odstraní artefakty a deformace obrazů. [7]

Účelem registrace obrazu je poskytnout páru, nebo několika obrazům téže scény pořízených různými způsoby, informace pro určení shodných prostorových bodů. To znamená, že ve výsledku by měl jakýkoliv pixel v každém z obrazů odpovídat stejné prostorové pozici na základním referenčním obraze. Geometrie zobrazování pro každý z obrazů je rozdílná v důsledku odlišných fyzikálních vlastností a jiného prostorového zkreslení zejména způsobeného porizováním odlišnými metodami.

Ze zarovnaných obrazů lze získat úplnější informace, např. umožňuje sledovat růst nádoru, ověřit úspěšnost léčby nebo srovnat údaje pacienta s anatomickými atlasy. Pro správnou registraci je proto nezbytné nalezení vhodné transformace a přenesení obrazu na základě geometrických dat, abychom mohli jednotlivé nesrovnalosti vykompenzovat a splnit tak podmínku úplného překrytí. Vzhledem k tomu, že se registrují různé typy scény s různým typem artefaktů, tak neexistuje univerzální postup, ale nespočet různých metod jak postupovat při registraci. Každá metoda by měla brát v úvahu předpokládaný typ deformace mezi obrazy a podle toho zvolit nejlepší volbu. Se zvyšujícím se výkonem počítačů můžeme zpracovávat objemnější data a používat složitější výpočetní techniky, které dříve nebylo možné použít. Nové algoritmy ulehčují celou řadu pracovních činností a umožňují nový náhled na řešený problém. [2], [3]

Cílem této práce je stručný výklad s teorií a různými typy používaných registrací. Použití registračních metod na MRI snímcích mozku a posouzení výsledků mezi používanými softwarovými nástroji.

# 1 DWI data a jejich předzpracování


Při použití EPI sekvence dochází ke snížení citlivosti nebo ztrátě signálu v okolí oblasti s velkou změnou magnetické susceptibility, což je také zdrojem výskytu jednoho z nejvýraznějších artefaktů. Mezi předzpracování řadíme potlačení těchto artefaktů operacemi, které připraví data ke statistické analýze. Dalšími kroky v předzpracování můžou být odstranění Gibsova artefaktu, korekce susceptibilních artefaktů, korekce vířivých proudů, korekce nehomogenity  $B_0$ , prostorová normalizace, která transformuje data do jednoho anatomického prostoru, výběr anatomicky důležitých oblastí, odstranění šumu a prostorové vyhlazování zvyšující poměr signál-šum pro usnadnění analýzy. [7]

Registraci obrazu můžeme chápat jako matematický problém, kdy hledáme vhodnou transformaci, kterou když aplikujeme na jeden snímek, tak by se měl, co nejpresněji geometricky překrývat. Z důvodu použití různých snímacích metod, bývají porovnávané obrazy rozdílně velké a je třeba je transformovat na stejnou velikost, kde se výsledné hodnoty voxelů přepočítají pomocí zvolené interpolace. Pokud obraz pochází ze stejné modality, tak je afinní transformace postačující, případně je změněná na rigidní. V případě, že se toto předpokládat nedá, musíme použít nelineární transformaci. V praxi rozhodnou o složitosti transformace pouze experimenty s reálnými daty. Když je vybrán typ transformace zbývá, určit konkrétní parametry transformace vedoucí k nejlepšímu proložení registrovaných snímků, a to buď přímo, nebo prostřednictvím optimalizace. Konečným cílem je přeměnit obraz  $T$  tak, že transformovaný obraz  $T'$  v překrývajících oblastech plně odpovídá obrazu referenčnímu. [9]

## 1.1 Difúzní vážení a b-hodnota

Než si vysvětlíme, co jsou difúzně vážené obrazy a jak je získáme je třeba si vysvětlit, co znamená b-hodnota. b-hodnota je faktor, který odráží sílu a časování impulzů používaných pro generování difúzně vážených obrazů z MRI. Podle rovnice uvedené v obrázku 1.1 víme, že čím vyšší je amplituda, doba trvání a čas mezi jednotlivými impulzy, tím je větší míra difúzního. [1]

Difúzně vážené obrazy DWI poskytují jedinečnou informaci o viabilitě tkániva v mozku. Výsledný kontrast je založen na pohybu molekul vody v tkáni, který bývá ovlivněn jednotlivými strukturami v mozku tak i patologickými stavy jako je ischemická nebo hemoragická cévní mozková příhoda. Difúzní zobrazení dále poskytuje informace o dalších typech mozkových onemocnění jako jsou intrakraniální infekce, traumatické poranění mozku a nebo o demyelinizačních změnách v axonech neuronů. [2]



Stejskal-Tanner pulsed gradient diffusion method.

$$b = \gamma^2 G^2 \delta^2 (\Delta - \delta/3)$$

Obr. 1.1: Vliv jednotlivých parametrů impulzů na výslednou b-hodnotu ( $G$  = síla gradientu,  $\delta$  = trvání gradientního pole,  $\Delta$  = čas mezi jednotlivými gradientními pulzy) - převzato z [1]

Pro výpočet difúzních parametrů je třeba použít snímek bez difuzního vážení, kde b-hodnota se rovná 0 a druhý snímek je s nenulovou hodnotou (nejčastěji  $1000 \text{ s mm}^{-2}$ ). Diffusion tensor imaging (DTI) rozšiřuje základní DWI model o nasnímaní objektu za použití minimálně šesti gradientních směrů [3]. Z takto nasnímaných dat je následně získán difúzní tenzor, který charakterizuje velikost a směr difúze v 3D prostoru. Pohyb vody v předpokládá klasické Gaussovské rozložení pro kapaliny. [3]


Výsledná intenzita obrazu naměřeného s nenulovým gradientním pulzem pro jeden voxel  $S$  je stanovena na základě rovnice:

$$S = S_0 e^{-bD}, \quad (1.1)$$

kde hodnota  $S_0$  odpovídá intenzitám T2-váženého obrazu bez gradientního impulzu (neboli  $b = 0 \text{ s mm}^{-2}$ ) a  $D$  difúznímu koeficientu.

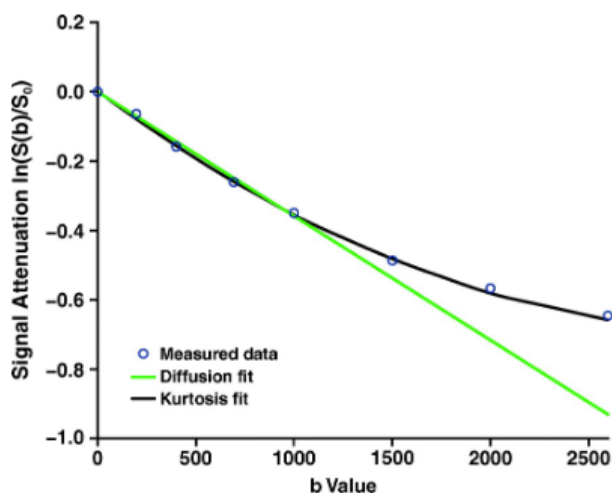
Jelikož tento model neodpovídá pohybu vody uvnitř biologických struktur, tak byl zaveden Diffusion kurtosis imaging (DKI) model, který je charakterizován nasnímáním minimálně 21 jednotlivými gradientními směry a použitím většího množství různě velkých b-hodnot. Obecně platí, že čím více směrů a b-hodnot, tím se metoda stává náročnější a přesnější. Dále rozšiřuje rovnici pro difúzní obrazy o parametr  $K$ , který je znázorněn na obrázku 1.2 popisuje ne-Gaussovské rozložení difúze. [3]

$$S = S_0 e^{-bD + b^2 D^2 K/6}, \quad (1.2)$$



Obr. 1.2: Parametr  $K$  a jeho pravděpodobnostní distribuce difúze vody,  $K = 0$  odpovídá Gaussovskému rozložení.

Na následujícím obrázku 1.3 lze vidět jak se s narůstající  $b$ -hodnotou více projevuje ne-gaussovské rozložení a tím výsledná intenzita signálu.




Obr. 1.3: Pokles intenzity signálu při zvyšující se  $b$ -hodnotě pro DTI a DKI - převzato z [3]

### 1.1.1 Frakční anizotropie

Z naměřených difúzních dat ve více směrech se sestaví tenzor. Tento tenzor je matematicky vyjádřený jako matice  $3 \times 3$ . Na jeho diagonále se pak nachází hodnoty  $\lambda_1$ ,  $\lambda_2$  a  $\lambda_3$  popisující velikost difúze ve třech na sebe kolmých směrech. Z takto získaných dat je vypočítaná mapa frakční anizotropie (FA) jako porovnávání hodnoty  $\lambda$

s jejich vzájemným průměrem. Mapa FA pak nabývá hodnot od 0 do 1. V případě, že se hodnoty  $\lambda_1 = \lambda_2 = \lambda_3$  tak výsledná hodnota frakční anizotropie = 0 a difúze je v tomto místě izotropní podobající se kouli, jestliže se ale jednotlivé hodnoty odlišují tak frakční anizotropie může dosáhnout až hodnoty 1, kdy je difúze plně anizotropní a podobá se podlouhlému elipsoidu. [3]

$$FA = \sqrt{\frac{(\lambda_1 - \lambda_2)^2 + (\lambda_2 - \lambda_3)^2 + (\lambda_1 - \lambda_3)^2}{2(\lambda_1^2 + \lambda_2^2 + \lambda_3^2)}} \quad (1.3)$$




Obr. 1.4: Zobrazení difúzního elipsoidu, nalevo izotropní a napravo anizotropní případ.

### 1.1.2 CHARMED model

Data s vysokou měrou difúzního vážení (vysokou b-hodnou) mají výrazně jiný kontrast v obraze, navíc vlivem silnějších gradientních mg. polí mají i větší artefakt způsobený vířivými proudy. Proto podle některých odborných článků dochází k systematické chybě v koregistraci obrazů výrazně různými b-hodnotami. Zatímco v rámci obrazů s podobnými b-hodnotami běžné nástroje fungují bez problémů. [26] Proto byl pro taková data navrhnut model CHARMED (Composite Hindered and Restricted Model of Diffusion), který počítá s reálnější představou, že zdroj signálu není výsledkem jednoho typu difúze ale kombinací více difúzí. Jako příklad můžeme uvést dva typy difúze probíhající v oblasti, kde se nachází bílá hmota mozková skládající se z jednotlivých nervových vláken. V těchto vláknech probíhají dva typy

difúze a to uvnitř jednotlivých neuronů kde difúze má více anizotropní charakter a pak pohyb vody mezi jednotlivými vlákny kde difúze probíhá volněji a má tedy více izotropní charakter. Dalším místem kde dochází k více typům difúzí jsou místa kde se jednotlivá vlákna kříží. CHARMED model tedy charakterizuje změnu signálu pomocí dvou tenzorů. Tento model je v práci dále využit pro vytvoření referenčních obrazů v registraci Matlabem. [5]



Obr. 1.5: Klasický difúzní model a CHARMED model

## 1.2 Artefakty v difúzních obrazech

### 1.2.1 Vířivé proudy (eddy currents)

Vířivé proudy jsou elektrické proudy indukované uvnitř vodiče vlivem rychle měnícího se magnetického pole. Při akvizici difúzních dat se využívá rychle měnících magnetických polí, které pak indukují proud ve vodičích. Tyto vířivé proudy produkují magnetické pole, které narušuje homogenitu magnetického pole a tím pak dochází ke ztrátě nebo posunu signálu. Takto narušený signál má za následek vznik artefaktů projevujících se jako posun, zkosení, kontrakce a lom ve výsledném obraze.

Vznik vířivých proudů lze minimalizovat použitím vhodných cívek s dostatečným stíněním, snížením vodivé plochy cívky a nebo nastavením hardwaru tak, aby korigoval vzniklé zkreslení vířivými proudy. Pokud i tak na snímcích tyto artefakty vzniknou dají se upravit vzájemnou koregistrací s obrazem bez difúzního vážení použitím 12 parametrické afinní transformace. [8], [25]



## 1.2.2 Susceptibilní artefakty

Susceptibilita je fyzikální veličina, která udává jaký bude mít vliv látka na magnetické pole. Materiály zeslabující magnetické pole se nazývají diamagnetické, mezi tyto látky v lidském těle patří hlavně kosti obsahující vápenaté soli. Materiály zesilující magnetické pole jsou nazývány paramagnetické, superparamagnetické a feromagnetické. Příkladem feromagnetických látek jsou převážně kovy jako je železo nebo kobalt. Mezi lehce paramagnetické látky se překvapivě řadí i kyslík. Právě na rozhraní s různou susceptibilitou vzniká největší zkreslení, to lze pozorovat v oblastech obsahující vzduch jako jsou nosní dutiny.

Samotné artefakty se projevují ztrátou signálu nebo jeho přemístěním a tím vznikem geometrických deformací. Jednou možností jak tyto artefakty eliminovat je nasnímání objektu ve dvou (nebo i více) směrech fázového kódování a stanovením homogenity statického magnetického pole, pomocí kterého se ostatní snímky upraví. [6]

## 1.3 Převzorkování obrazu

Před tím, než uvedeme jednotlivé typy převzorkování obrazu, je třeba uvést jeho interpretaci v digitální podobě. Získaný digitální trojrozměrný obraz je popsán maticí obrazových bodů (voxelů), obsahující rozměry jako  $x$ ,  $y$ ,  $z$  (šířka, výška, hloubka). [7]

Často jsou voxely jednotlivých obrazů, které chceme porovnat anizotropní a celkové rozměry obrazu se liší. Pokud tedy chceme aplikovat prostorové transformace mezi jednotlivými obrazy je třeba použít převzorkování. [7]

Převzorkováním je myšlena změna rozměru snímků, co do počtu pixelů. Počet pixelů můžeme snížit a tím ztratit některé informace, nebo můžeme počet zvýšit přidáním pixelů. Součástí tohoto procesu je určení intenzity pro každý pixel transformovaného obrazu odpovídající intenzitě originálního obrazu. Obvykle je potřeba použít nějaký druh interpolace mezi voxely.

### 1.3.1 Metoda nejbližšího souseda

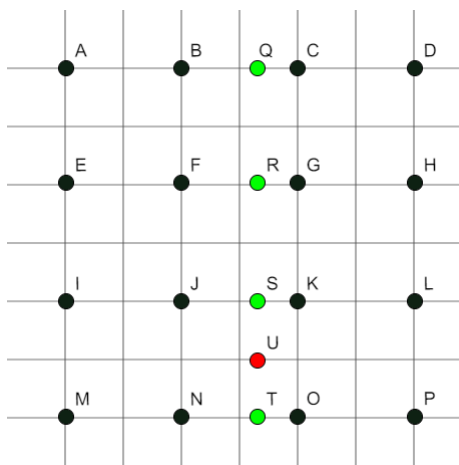
Jednou z nejjednodušších, ale velmi rychlých je metoda nejbližšího souseda. Tato metoda prostě zopakuje sousední pixel. To má stejný efekt jako zvětšení plochy pixelu. Zachovává sice původní intenzitu voxelu, ale produkuje silné rozostření obrázku. [7]

### 1.3.2 Metoda trilineární interpolace

Další možností je použití trilineární interpolace, kde se hodnota voxelu získává váženým průměrováním nejbližších osmi sousedících hodnot. Tato metoda je nejpoužívanějším typem interpolace. Je o něco pomalejší, než metoda nejbližšího souseda, ale

výsledný obraz je vyhlazenější. Nicméně může dojít ke ztrátě vyšších intenzit v obraze. [7]

Zde si uvedeme výpočet bilineární interpolace, jako zjednodušené formy trilineární interpolace ve dvou dimenzích. Pro ukázkou výpočtu hodnoty pixelu nám bude sloužit obrázek 1.6.



Obr. 1.6: Ilustrace interpolace dvoudimenzionálního obrázku. Body od A do P reprezentují původní pixely. Bod U je pixel, pro který bude vypočítána nová hodnota intenzity. Body Q až T slouží pro mezivýpočet.

Předpokládejme body o souřadnicích  $x_a, y_a$  až  $x_p, y_p$  s intenzitami od  $v_a$  do  $v_p$ . Hodnota intenzity pro převzorkovaný pixel U se vypočítá následovně. První je potřeba zjistit hodnoty intenzit u pixelů S a T za použití lineární interpolace.

$$v_s = \frac{(x_k - x_s)v_j + (x_s - x_j)v_k}{x_k - x_j} \quad (1.4)$$

$$v_t = \frac{(x_o - x_t)v_n + (x_t - x_n)v_o}{x_o - x_n} \quad (1.5)$$

Následně je pomocí interpolace mezi  $v_s$  a  $v_t$  vypočítána hodnota  $v_u$ .

$$v_u = \frac{(y_u - y_t)v_s + (y_s - y_u)v_t}{y_s - y_t} \quad (1.6)$$

### 1.3.3 B-spline interpolace

Další alternativou pro interpolaci je použití funkce b-spline. Díky ní, se dají rozložit složité polynomiální funkce na jednodušší polynomy nižších řádů. To se nejvíce projeví u funkcí vyšších řádů. Spline je podle definice „polynom po částech“. To znamená, že definiční obor složitého polynomu se rozdělí na intervaly a na každém z nich se definuje polynom nižšího řádu. Použití b-spline interpolace s řádem 0 se

rovná interpolaci nejbližšího souseda a s řádem 1 se dostáváme na klasickou lineární interpolaci. Tenhle druh interpolace je tedy rozšířením klasických interpolací o další polynomy. Zvolením řádu se dá nastavit jak kvalita interpolace tak i její rychlost a tím ušetření výpočetního času. [10]

## 1.4 Vyhlazování

Nasnímané obrazy mozku zpravidla obsahují šum, proto je třeba provést nějaký typ filtrace. Běžně se používá konvoluce Gaussovského filtru, při které dojde k rozmazání obrazu. Vlivem rozmazání dochází k normalizaci dat a tím i k lepším výsledkům ve statistické analýze. Dále se rozmazání uplatňuje v registraci, protože dochází ke zvýšení rozdílností mezi rozdílnými oblastmi. [11] Gaussovský filtr v 1D prostoru je definován jako :

$$K(t) = \frac{e^{-\frac{t^2}{2}}}{\sqrt{2\pi}}. \quad (1.7)$$

Nyní rovnici rozšíříme o hodnotu šířky pásma  $\sigma$ :

$$K_\sigma(t) = \frac{1}{\sigma} K\left(\frac{t}{\sigma}\right). \quad (1.8)$$

Šířka pásma  $\sigma$  udává rozsah filtrované oblasti. Při zobrazování mozku bývá rozsah oblasti definován jako *full width at the half maximum* (FWHM) gaussova filtru  $K_\sigma(t)$ :

$$FVHM = 2\sqrt{2 \ln 2} \sigma. \quad (1.9)$$

Hodnota FWHM se zvyšuje lineárně se zvyšující se  $\sigma$  v euklidovském prostoru. Pro vyhlazení se volí hodnota FWHM přibližně jako trojnásobek velikosti voxelů v mm. N-dimenzionální gaussovský filtr je definován pomocí  $n$  1D vektorů.


$$K_\sigma(t) = K_\sigma(t_1) K_\sigma(t_2) \cdots K_\sigma(t_n) \quad (1.10)$$

$$K_\sigma(t_n) = \frac{1}{(2\pi)^{n/2} \sigma^n} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n t_i^2\right). \quad (1.11)$$


Podoba vzorce pro 2D gaussovský filtr, pokud uvažujeme  $r^2 = t_1^2 + t_2^2$  vypadá následovně:

$$K_\sigma(r) = \frac{e^{-\frac{r^2}{2\sigma^2}}}{2\pi\sigma^2}. \quad (1.12)$$

Konvoluce 2D obrazu s 2D gaussovským filtrem probíhá v jednom směru a následně v druhém. Pokud chceme použít konvoluci pro 3D obraz stačí přidat další konvoluci ve třetím směru.



Obr. 1.7: Ilustrace 2D Gaussova filtru s různými hodnotami  $\sigma$ .



Obr. 1.8: Konvoluce s 2D gaussovským filtrem. Původní obrázek je konvolován horizontálně a následně vertikálně - převzato z [9]

## 1.5 Afinity transformace

Jedna ze základních a nejčastěji používaných prostorových transformací je afinity transformace, zprostředkovávající rotaci, translaci, zkosení a změnu velikosti. Každý bod  $(x_1, x_2, x_3)$  z původního obrazu lze přepočítat do nového souřadnicového systému  $(y_1, y_2, y_3)$ . To je vyjádřeno soustavou rovnic:

$$\begin{aligned} y_1 &= m_{11}x_1 + m_{12}x_2 + m_{13}x_3 + m_{14} \\ y_2 &= m_{21}x_1 + m_{22}x_2 + m_{23}x_3 + m_{24} \\ y_3 &= m_{31}x_1 + m_{32}x_2 + m_{33}x_3 + m_{34} \end{aligned} \quad (1.13)$$

Často je tenhle přepočet vyjádřen pomocí maticového násobení ( $y = Mx$ ):

$$\begin{pmatrix} y_1 \\ y_2 \\ y_3 \\ 1 \end{pmatrix} + \begin{pmatrix} m_{11} & m_{12} & m_{13} & m_{14} \\ m_{21} & m_{22} & m_{23} & m_{24} \\ m_{31} & m_{32} & m_{33} & m_{34} \\ 0 & 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ x_3 \\ 1 \end{pmatrix} \quad (1.14)$$

Výhodou formulací těchto rovnic pomocí matic je, že může být realizováno několik transformací jen vzájemným násobením matic za účelem vytvoření jediné matice. [12], [9]

### 1.5.1 Rigidní transformace


Pro koregistraci obrazů odlišující se pozicí jsou používány rigidní transformace, které spadají do afinních transformací. Tyto transformace zprostředkovávají operace jako je posun a rotace ve směru ortogonálních os. Ve třídídimenzionálním prostoru jsou definovány šesti parametry, kterými jsou posunutí ve směru os x, y, z a rotace  $\varphi_1$ ,  $\varphi_2$ ,  $\varphi_3$ , kolem těchto os. Matice posunutí ve směru osy x, y nebo z je zde definována pomocí tří parametrů  $x_{trans}$ ,  $y_{trans}$  a  $z_{trans}$ . V maticovém zápisu vypadá posunutí následovně:

$$\begin{pmatrix} 1 & 0 & 0 & x_{trans} \\ 0 & 1 & 0 & y_{trans} \\ 0 & 0 & 1 & z_{trans} \\ 0 & 0 & 0 & 1 \end{pmatrix} \quad (1.15)$$

Matice pro přepočítání rotace ( $\varphi$  - v radiánech) ve směrech x, y a z os jsou:

$$\begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & \cos \varphi & \sin \varphi & 0 \\ 0 & -\sin \varphi & \cos \varphi & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix}, \begin{pmatrix} \cos \varphi & 0 & \sin \varphi & 0 \\ 0 & 1 & 0 & 0 \\ -\sin \varphi & 0 & \cos \varphi & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix}^a \begin{pmatrix} \cos \varphi & \sin \varphi & 0 & 0 \\ -\sin \varphi & \cos \varphi & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix} \quad (1.16)$$

Výsledný obraz vznikne kombinací násobení těchto matic, proto záleží na pořadí, ve kterém tyto operace probíhají. Například rotace ve směru osy x o  $\pi/2$  s následně stejně velkou rotací ve směru osy y by produkovala jiný obraz, nežli ta samá operace probíhající pozpátku. [12], [9]



Obr. 1.9: Vlastnosti afinní transformace. Zleva doprava je to translace, rotace, změna velikosti a skosení.

## 1.6 Optimalizace

Jednou z hlavních částí registrace obrazů je optimalizace. Jejím úkolem je určení takové transformační funkce, při níž se budou výsledné obrazy překrývat, takže jejich podobnost bude maximální. Cíl optimalizace lze tedy chápat jako určení sady parametrů, pro které má funkce minimální nebo maximální hodnotu. Pro správnou registraci medicínských obrazů je důležité zabránit uvíznutí v lokálním minimu, proto stoupá na popularitě použití globálních metod, které tohle kritérium splňují. Globálních optimalizačních metod existuje velké množství, zde si uvedeme jen pár používaných.

### 1.6.1 Kriteriální funkce

Kriteriální funkce jsou nejčastěji používanou metodou pro nalezení podobnosti registrovaných obrazů. Existuje spousta různých modifikací kriteriálních funkcí, některé využívají znalostí geometrických znaků nalezených v obraze pro určení rozdílností a jiné pracují přímo s hodnotami intenzit obrazů. Jedním z nejběžnějších problémů registračních metod je přítomnost lokálních minim. Ty způsobují, že dojde k uvíznutí funkce v lokálním minimu a nedojde k nalezení globálního minima. Většina metod řeší tento problém pomocí lokální optimalizační strategie. Taková strategie typicky zahrnuje práci s obrazem s nízkým rozlišením a postupně se propracovává až k vyššímu rozlišení. Běžně používané kriteriální funkce pro registraci jsou ty pracující s intenzitami, jako je metoda nejmenšího čtverce (LS), normalizovaná korelace (NC), korelační poměr (CR) nebo vzájemná informace (MI). Níže si uvedené metody vyjádříme matematicky, kde vektory  $X$  a  $Y$  obsahují intenzity porovnávaných obrazů a  $H(X, Y)$  vyjadřuje sdruženou entropii obrazů,  $H(X)$  a  $H(Y)$  jsou marginální entropie jednotlivých obrazů,  $Var(Y)$  je rozptyl,  $Y_k$  množina intenzit z obrazu  $Y$ ,  $n_k$  je počet prvků v množině  $Y_k$  a  $N$  je jejich součet. [13]

Vzorec pro metodu nejmenšího čtverce (LS):

$$C^{LS} = \sum (Y - X)^2. \quad (1.17)$$

Vzorec pro normalizovanou korelaci (NC):

$$C^{NC} = \frac{\sum (X \cdot Y)}{\sqrt{\sum X^2} \sqrt{\sum Y^2}} \quad (1.18)$$

Vzorec pro vzájemnou informaci (MI):

$$C^{MI} = H(X, Y) - H(X) - H(Y) \quad (1.19)$$

Vzorec pro korelační poměr (CR):

$$C^{CR} = \frac{1}{Var(Y)} \sum_k \frac{n_k}{N} Var(Y_k) \quad (1.20)$$

## 1.6.2 Genetické algoritmy

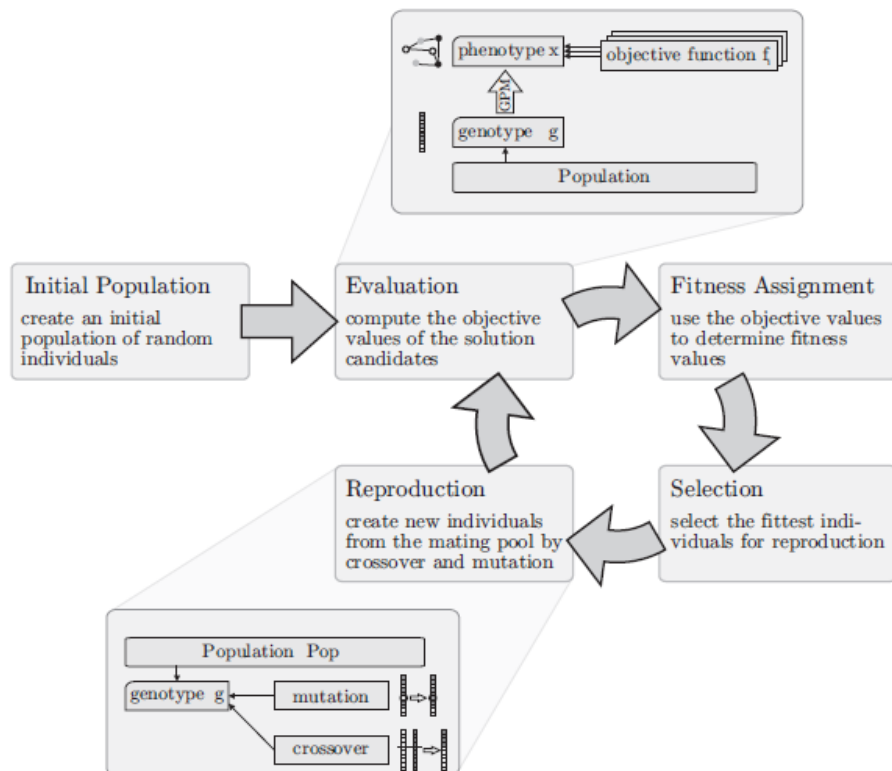
Počátek genetických algoritmů se datuje do období 50. let minulého století. Princip této metody je založen na vývoji druhů, kde potomci dědí vlastnosti rodičů a jen silnější a přizpůsobivější jedinci přežijí. Jedinec může být reprezentován např. jako binární číslo. Množina různých řešení jedinců tvoří populaci. Následně se s takto rozdělenými jedinci provádí tři níže popsané operace. [14], [15]

**Selekce** je operace, kde se každému jedinci v populaci přiřadí fitness hodnota. Ta vyjadřuje míru schopnosti jedince přežít a plodit další potomky. Během selekce se odstraňují potomci s nízkou fitness hodnotou.

**Křížení** navazuje na selekci tím, že kombinuje části jedinců mezi sebou a tak zvyšuje variabilitu. Křížením vzniknou nové jedinci, u kterých je třeba zvážit jestli je ponechat oba a nebo vybrat jen jednoho.

**Mutace** je konečná část genetického algoritmu. Dochází zde k částečným změnám jedince. V případě binárních reprezentací dojde k záměně 0 za 1. Mutací může vzniknout informace, která v předchozí generaci nebyla nebo byla ztracena, zároveň zabráňuje sklouznutí do lokálního optima.

Celý proces se opakuje dokud není splněna ukončovací podmínka, např.: počet cyklů, nalezení minimální hodnoty nebo dokud je nová generace lepší než ta stará.



Obr. 1.10: Jednoduchý cyklus genetického algoritmu - převzato z [14]

### 1.6.3 Metoda roje částic

Metoda roje částic je stochastická metoda inspirovaná chováním živočichů v rojích nebo hejnech. Vysvětlení metody provedeme na příkladu roje včel hledajících potravu.

Když se roj vydá hledat potravu tak se jednotlivé včely nezávisle na sobě rozmístí po okolí. Jakmile nějaká včela nalezne potravu tak si zapamatuje pozici, kterou objevila. tato včela informuje ostatní včely o poloze a sama dostává informace o ostatních polohách. Zároveň je informována o celkové nejlepší poloze celého roje. Tyto včely stále přelétávají a hledají lepší polohu. Na tomto principu je celé pole prozkoumáno a roj skončí na místě s nejlepší pozicí. [16]

## 1.7 Registrace obrazů

Koregistrace obrazu je velmi důležitou součástí jak pro výzkum v medicíně, tak i pro určení stavu pacienta na základě jejich porovnání. Registrované obrazy se dělí na monomodální, které jsou získané stejnou zobrazovací metodou a multimodální, získány různými modalitami, např. pomocí PET a MRI. V téhle práci se zabýváme monomodální koregistrací MRI obrazů mozku. Nejčastěji se provádí korekce pohybu, protože nelze zcela zabránit pacientovi v pohybu hlavy během snímání. Cílem koregistrace je tedy provedení takové operace, aby se jednotlivé obrazy překrývaly a bylo možné rozeznat změny ve struktuře tkáně. Do registrace vstupují dva obrazy: jeden referenční  $F$ , ten je ponechán beze změn a druhý plovoucí  $G$ , který je zarovnán podle referenčního obrazu. [9], [12], [17]



## 2 Softwarové nástroje

### 2.1 AFNI

Softwarový nástroj, Analysis of Functional NeuroImages, byl vyvinut Robertem W. Coxem v roce 1994 na Medical College of Wisconsin.

Jak už jeho název vypovídá zaměřuje se na zpracování, analýzu a zobrazení dat z fMRI ve formátu NIfTI. Je to volně dostupný program psaný v C kódu spustitelný v Linuxu nebo na MacOS, dnes se nabízí možnost ho spustit i na Windows 10 s nainstalovaným Linuxem. Nabízí řadu metod jako jsou překrytí funkčního obrazu s anatomickým, převod do standardizovaného formátu, transformace, grafy, výpočet funkčních map a registraci.

Pro naše účely je důležité, že umožňuje práci s difusními daty. Zjednodušený postup registrace spočívá v korekci artefaktů a registraci pomocí afinní transformace a nakonec použití nelineární funkce pro přidání difuzních tensorů. Součástí AFNI je nástroj SUMA, který umožňuje zobrazení 2D dat do 3D mapy kortikálního povrchu a tím brát v úvahu fyzické rysy povrchu mozku. [18]

### 2.2 SPM

Statistical Parametric Mapping je volně dostupný softwarový nástroj původně vyvinut Karlem Fristonem pro analýzu dat z pozitronové emisní tomografie.

V dnešní době slouží pro analýzu sekvencí obrazových dat mozku pocházejících z různých modalit a nebo jen časových snímků jednoho subjektu. SPM je navržen tak aby umožnil zpracování dat z fMRI, PET, SPECT, EEG a EMG. Samotný software lze nainstalovat na operační systémy jako je Microsoft Windows, Linux a MacOS.

Grafické prostředí je spouštěno jako funkce v Matlabu a nebo se dá stáhnout samostatná verze nevyžadující licenci Matlabu s omezenými možnostmi. Podporované formáty pro zpracování jsou NIfTI-1, GIFTI, DICOM. V nejnovější verzi SPM12 z roku 2014 také začíná podporovat NIfTI-2, který dokáže uchovávat objemnější data. Základní předzpracování se skládá ze zarovnání, normalizace, segmentace, vyhlazení a koregistrace. Pro samotný software se dá stáhnout obrovské množství knihoven. Jedním z nich je i knihovna pro zpracování difusně vážených obrazů. Mezi jeho základní funkce patří pohybová korekce, stanovení difuzního tensoru a výpočet anizotropie. [19]

## 2.3 FSL

FMRIB Software Library je nejrozšířenějším nástrojem pro práci s DWI daty, který byl vyvinut členy Functional MRI of the Brain v Oxfordu UK. První verze byla vydána v roce 2000.

Dnes existuje už šesté vydání (verze 6.0.3), které lze spustit jak na MacOS tak i v Linuxu popřípadě ve Windows pomocí virtual boxu nebo využitím interpretovaného příkazového řádku v Ubuntu prostředí. Samotné spuštění lze realizovat příkazovým řádkem a nebo přes grafické prostředí. Analyzovaná data jsou načtená z NIFTI-1 formátu. Součástí softwaru je rozsáhlá knihovna funkcí jako jsou extrakce mozku, segmentace, redukce šumu, analýzy voxelů a registrace. Dále lze stáhnout související software v podobě modulů, nástrojů, šablon a dalších rozšíření. [20]

## 2.4 Elastix

Elastix vznikl v roce 2003 díky Stefanu Kleinovi a Mariusu Staringpodovi na Univerzitě Medical Center Utrecht pod dohledem Josiena P. W. Pluma.

Původně byl zamýšlen jen pro univerzitní výzkum, ale v roce 2004 byl oficiálně vydán jako volně dostupný software. Samotný software je multiplatformní a spouští se pomocí příkazového řádku a nebo pomocí stáhnutelného toolboxu do Matlabu. Velká část algoritmů pro registraci medicínských obrazů je založena na Insight Segmentation and Registration Toolkit. Webové stránky disponují celou řadou příkazů pro nastavení jednotlivých kroků jako je optimalizace, interpolace, transformace a registrace. Dnes lze stáhnout SimpleElastix, který zpřístupňuje Elastix v jiných programových jazycích jako je C++, Python nebo Java. [21], [22]

## 2.5 ITK

ITK je volně dostupným softwarovým balíčkem pro registraci a segmentaci obrazu. Počátek vývoje nastal v roce 1999 za pomoci US National Library of Medicine of the National Institutes of Health.

Je programován v jazyce C++ a díky tomu, může kdokoliv přispět rozšířením kódu a nebo jeho úpravou. Pomocí CMake kompilátoru je spustitelný na všech platformách. Samotný program nevyžaduje přesný formát dat, ale umožňuje nahrání jakéhokoliv formátu s jeho dodatečnou úpravou. [10].

## 2.6 MATLAB

MATLAB (matrix laboratory) je interaktivní programové prostředí a skriptovací programovací jazyk. Vytvořil ho na konci sedmdesátých let profesor Cleve Moler. V letech 1984 vznikla společnost MathWorks, která dále pokračuje ve vývoji a nabízí ho jako placený software pro práci s maticemi, vykreslování 2D i 3D grafů funkcí, implementaci algoritmů, počítačovou simulaci, analýzu a prezentaci dat i vytváření aplikací včetně uživatelského rozhraní.

Nejčastěji je Matlab používán převážně pro vědecké a výzkumné účely. Samotný program nabízí vlastní možnosti registrace obrazu a nebo umožňuje spuštění algoritmů z jiných programů za pomoci rozšiřujících knihoven. V naší práci využíváme verzi 9.9.0.1467703 (R2020b).

## 2.7 3D Slicer

3D Slicer je volně dostupný softwarový balík určený pro práci s medicínskými daty a to jak ve formě 3D vizualizace dat, tak jejich zpracováním pomocí modulů, jako jsou segmentace, registrace, vykreslení objemu a extrakce kostry. K možnostem interaktivní vizualizace 3D Sliceru patří schopnost zobrazovat obrazy v libovolně orientovaných řezech, vytvářet modely povrchů zobrazovaných objektů. [23]

Některé moduly jsou už nainstalovány v samotném programu, ale je možnost rozšíření o externí moduly. Podporuje standardní medicínské formáty jako jsou NIFTI nebo DICOM. Samotný program je podporován na běžných operačních systémech: Windows, Linux, MacOSX.

## 3 Metody hodnocení registrace

Následující kapitola obsahuje popis metod pro vyhodnocení kvality koregistrací s jejich ukázkami. Mezi uvedené metody jsme zařadili porovnání vybraných oblastí vůči referenčnímu bodu, rozdíl mezi transformačními parametry, srovnání intenzit vybraného řezu, histogram, a šachovnici, Extrapolační metoda pomocí CHARMED.

### 3.1 Koregistrace FA obrazů

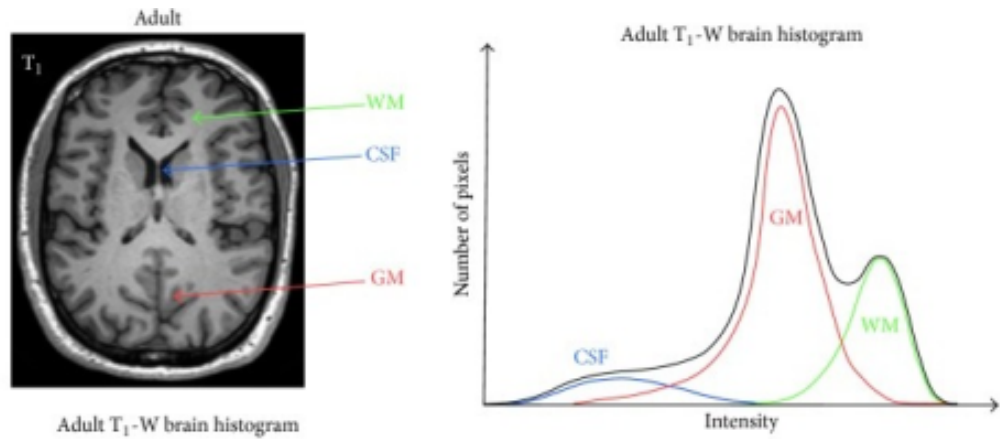
K posouzení kvality registrace difúzně vážených dat navrhl Nilsson et al. vyjít z předpokladu, že obrazy frakčních anizotropií vypočítané z nízkých i vysokých  $b$  hodnot mají velmi podobný kontrast a (narozdíl od výchozích obrazů). Lze tedy jejich případný nesoulad, nesprávnou koregistraci odhalit. Prakticky to navrhli provést koregistraci v dostupném programovém prostředí (např. fsl) přičež výstupní transformační matice dává poměrně přesnou informaci o tom o kolik se obrazy s vysokým a nízkým  $b$  od sebe odlišovaly. Pokud by koregistrace mezi jednotlivými difúzními obrazy byla úspěšná tak FA obrazy složené z těchto dat by při vzájemné koregistraci neměli produkovat posun, rotaci, zkosení a zvětšení v žádném směru transformační matice [24]

### 3.2 Vizuální kontrola

Jednou z nejpraktičtějších a také nejběžnějších metod jak porovnat úspěšnost registrace je vizuální kontrola porovnávaných obrazů, nejlépe lékařským odborníkem. Nejčastěji se vybere určitá část v obrazech do, které se vykreslí geometrický útvar na stejných souřadnicích pro všechny porovnávané obrazy. Geometrický útvar slouží jako opěrný bod pro přesnější vizualizaci a posouzení nepřesnosti mezi registrovanými obrazy. Lze tak snadno určit, která metoda je úspěšnější a nebo jakým způsobem nastavit další kroky registrace. [24]

### 3.3 Histogram


Histogram je další používaná metoda pro analýzu rozložení hodnot intenzity v obraze. Pomocí histogramu můžeme transformovat hodnoty obrazu tak, že dojde ke změně kontrastu a nebo rozložení barev. Touto změnou se tedy docílí lepšího subjektivního dojmu, snazší analýzy, klasifikace a zvýšení diagnostické výtěžnosti.



Obr. 3.1: Histogram T1 váženého obrazu mozku. Na ose x se nachází hodnoty intenzity pixelů a na ose y je počet pixelů obsahující danou intenzitu.

### 3.4 Joint histogram


Joint histogram pro dva obrázky je tvořen maticí  $M \times N$ , kde  $M$  obsahuje hodnoty intenzit v prvním obrázku a  $N$  hodnoty druhého. Pokud jsou porovnávány obrázky identické, na diagonále v joint histogramu se objeví ostrá přímka. Čím víc jsou obrázky odlišné, tím víc se v joint histogramu projeví odlišnost od diagonály. Podle celkové ostrosti lze posoudit kvalitu registrace.



Obr. 3.2: Rozdíl mezi registrovaným a neregistrovaným joint histogramem

### 3.5 Šachovnice

Další metodou pro rychlé porovnání registrovaných obrazů je použití šachovnice. Referenční a transformovaný obraz jsou rozděleny na podobrazy a umístěny do šachového pole, kde světlejší pole zabírá referenční obraz a tmavé pole transformovaný obraz. [10]




Obr. 3.3: Šachovnice složená z podobrazů, vlevo před registrací vpravo po registraci  
- převzato z [10]

## 4 Ověření funkčnosti daných nástrojů a pracovní postup

### 4.1 Použitá data

Soubor dat se skládá z mono-modálních difúzně vážených MRI snímků jednoho subjektu. Data byly nasnímané na Siemens Prisma skeneru v laboratořích CEITEC MU. Data byly nasnímané difúzní EPI sekvencí (Echo Planar Imaging) s parametry: TE = 78 ms, TR = 9000 ms a BW 1940 Hz/Px. Tato data jsou ve formátu NIfTI-1 a obsahují 100 jednotlivých 3D obrazů mozku o rozměrech  $112 \times 112 \times 64$  voxelů s prostorovým rozlišením  $2\text{mm} \times 2\text{mm} \times 2\text{mm}$  a FOV  $224\text{mm} \times 224\text{mm} \times 128\text{mm}$ . Data byla nasnímaná ve směru fázového kódování anterior-posterior (AP), z toho deset obrazů bylo nasnímano bez difúzního vážení,  $b = 0 \text{ s mm}^{-2}$  a zbytek dat obsahovaly difúzně vážené obrazy s b-hodnoty 700, 1000 a 2300, pro každou b-hodnotu bylo zvoleno 30 jednotlivých gradientních směrů.



Obr. 4.1: Použitá data s jejich b-hodnotami, nahoře obraz A = 0, B = 700, dole obraz C = 1000 a D = 2300 s  $\text{mm}^{-2}$ .

## 4.2 Kontrola dat

Nasnímaná data je potřeba vizuálně zkontrolovat. Při tomto procesu se prochází jednotlivé snímky a pozorují se geometrické deformace, výpadky signálu, množství šumu a chybějící řezy. Důležitou součástí pro zpracování nasnímaných dat je kontrola naměřených parametrů. V našem případě jsou to hlavně textové soubory obsahující b-hodnoty všech získaných obrazů ve správném pořadí a k tomu soubor `bvecs`, obsahující  $3 \times 1$  vektor pro každý směr gradientního pole. Takto zkontrolovaná data můžeme následně zpracovávat.

## 4.3 Registrace pomocí FSL

Prvním krokem v registraci byla korekce susceptibilních artefaktů vzniklých rozdílnou susceptibilitou v zobrazované oblasti hlavy a způsobením lokálních změn intenzity magnetického pole. Pro tuto korekci jsme použili celkem šestnáct obrazů bez difúzního vážení, deset obrazů bylo kódováno ve směru anterior-posterior a šest kódováno v opačném směru a to posterior-anterior. Tyto obrazy bylo potřeba sjednotit do jednoho souboru, k tomuto účelu byla použita funkce `fslmerge`. Pro sjednocená 4D data byl vytvořen soubor `acqparams` obsahující informace o fázovém kódování. Sjednocené obrazy spolu s akvizičními parametry byly vloženy do funkce `topup`, která využívá pro výpočet homogenity statického magnetického pole faktu, že se susceptibilní artefakty propagují ve směru fázového kódování. Výstupem této funkce jsou upravené vstupní obrazy bez susceptibilních artefaktů a odhad homogenity statického magnetického pole, která popisuje jakým způsobem tělo pacienta deformuje výsledný obraz. Výstupní data sloužila k vytvoření průměrného obrazu pomocí `fslmaths`, z tohoto obrazu byla extrahována mozková část bez lebky pomocí funkce `bet`.

Následně byla zvolena funkce `eddy`, která aplikuje korekci susceptibilních artefaktů na celý náš data set. Zároveň upravuje pohybové artefakty registrováním vůči prvnímu obrazu s  $b = 0 \text{ s mm}^{-2}$ . Vstupní data pro `eddy` obsahují původní data set, ořezaný snímek mozku, akviziční parametry, výsledky z `topup` funkce, soubory `bval` a `bvecs`. Registrace využívá klasické afinní transformace skládající se z posunu, rotace, zkosení a změny velikosti, pro interpolaci byla zvolena metoda spline.

Dalším krokem po `eddy` korekci byla registrace s referencemi vytvořenými jako průměry jednotlivých b-hodnot. Pro vytvoření referencí se musela data po `eddy` korekci rozdělit na samostatné soubory obsahující jednotlivé výběry b-hodnot, k tomu byla vybrána funkce `fslmath`. Protože registrace probíhala mezi daty se stejnou intenzitou a z jedné akvizice byla zvolena 6-parametrická afinní transformace, metoda nejmenších čtverců jako minimalizační funkce a spline interpolace.



Data po registraci jsme rozdělili na dva soubory, jeden obsahující nízké b-hodnoty ( $700, 1000 \text{ s mm}^{-2}$ ) a soubor s b-hodnoty  $2300 \text{ s mm}^{-2}$ . Na takto připravená data jsme aplikovali `dtfit`, který stanoví difúzní tensorový model pro každý voxel v obraze. Vstupy pro funkci obsahují sérii zarovnaných 4D dat upravených od vířivých proudů, mozkovou masku a soubory `bvals` a `bvecs` informující o směru gradientů a jejich b-hodnoty. Výstupem této funkce jsou FA obrazy s nízkými a vysokými b-hodnotami jejichž intenzita se pohybuje mezi 0 a 1. V případě izotropní difúze je hodnota rovna 0 a v případě úplné anizotropie se hodnota rovná 1.

## 4.4 CHARMED registrace v matlabu

Ve vývojovém prostředí Matlab jsme využili open-source toolbox Multidimensional diffusion MRI vytvořený Markusem Nilssonem. Tento toolbox zprostředkovává soubor funkcí pro analýzu multidimenzionálních difúzních dat. [26], [24]

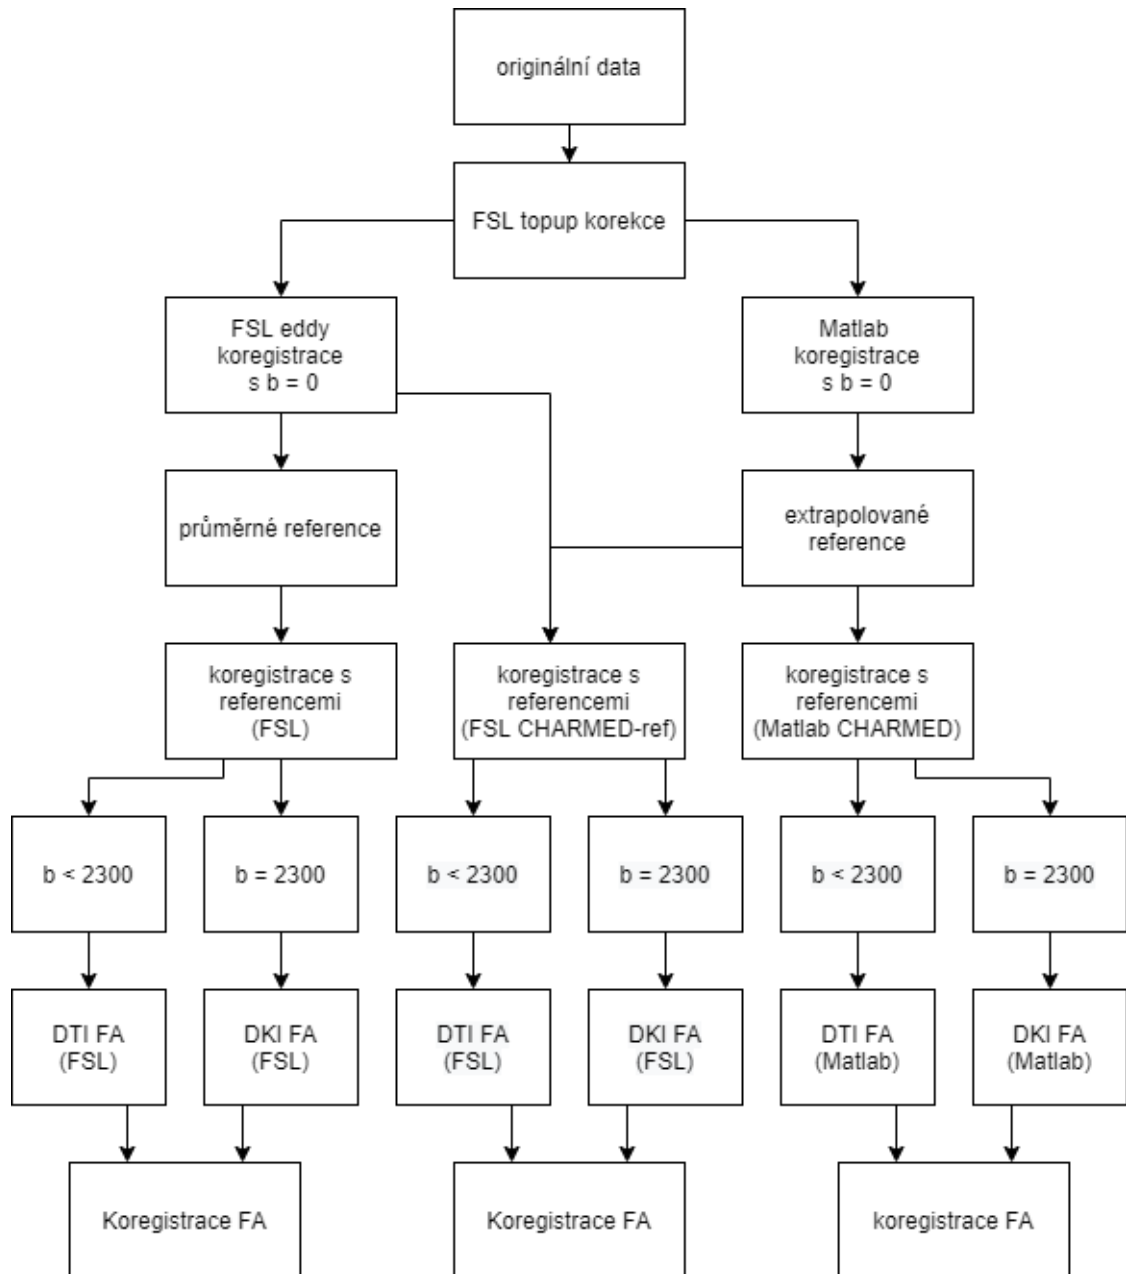
Stejně jako v registraci pomocí FSL, byla prvním krokem úprava dat od susceptibilních artefaktů. K tomuto účelu jsme využili funkci v FSL `applytopup`, kterou využívá i samotný toolbox. Dalším krokem bylo nastavení registračních parametrů, pro tento účel využívá toolbox stejné parametry jako Elastix. Jako minimalizační funkce byla nastavena společná informace a spline interpolace. Data upravená od susceptibilních artefaktů a soubor s Elastix parametry byly vloženy do registrační funkce `mdm_s_mec`. Tato funkce vykonává dvě registrace po sobě. První registrací je klasická registrace vůči obrazu s  $b = 0 \text{ s mm}^{-2}$ . Druhou částí registrace je vytvoření referenčních obrazů z nízkých b-hodnot. Pro vytvoření referenčních obrazů se využívá CHARMED metoda, která simuluje intenzitu signálu složením dvou tenzorů popisujících dva typy difúze.

Posledním krokem bylo vytvoření FA obrazů z nízkých a vysokých b-hodnot použitím funkcí `dti_11s_pipe` a `dki_11s_pipe`. Dále jsme využili CHARMED model reference a provedli registraci v FSL s daty, které prošly eddy korekcí v FSL. Registrace byla provedena pomocí příkazu `flirt` s nastavením minimalizační funkce společná informace a spline interpolace. Z dat registrovaných vůči CHARMED referencím jsme následně vytvořili FA obrazy pomocí funkce `dtfit`.

## 4.5 FA koregistrace

K posouzení přesnosti registrace jsme zvolili metodu kdy jsme předpokládali, že pokud jsou data z nízkých a vysokých b-hodnot správně koregistrovaná, tak při koregistraci mezi FA obrazy sestavených z těchto dat by nemělo dojít k žádnému

posunu, rotaci, zkosení nebo roztáhnutí. Tuto představu jsme realizovali jako koregistraci mezi referenčním FA obrazem složeným z dat s nízkou mírou difúzního vážení vůči FA obrazu s vysokou mírou difúzního vážení s použitím 12 parametrické afinní transformace a společné informace jako minimalizační funkce. Z takto koregistrovaných dat jsme vyhodnotili jejich úspěšnost pomocí transformačních parametrů. Na obrázku 4.2 jsme uvedli diagram celého registračního procesu.



Obr. 4.2: Diagram registračního procesu zobrazující tři metody provedené pomocí programu FSL a Matlabu.

## 5 Zhodnocení výsledků a diskuze


### 5.1 Vyhodnocení FA koregistrace

Úspěšnost registrace pro klasický a extrapolovaný model jsme porovnávaly na základě vzájemné registrace FA obrazů vytvořených z dat s nízkou mírou difúzního vážení a FA obrazů vytvořených z dat s vysokou mírou difúzního vážení. Jelikož měli všechny porovnávané FA obrazy stejný kontrast tak jsme provedli vizuální porovnání mezi vybranými oblastmi. Jako hlavní porovnávanou oblast jsme vybrali největší svazek nervových vláken zvaný "korpus kalosum", který spojuje obě hemisféry mozku a zprostředkovává jejich vzájemnou komunikaci. Pro porovnání byly zvoleny oba výsledné FA obrazy vytvořené běžnou metodou a obrazy z vysokých hodnot použitím extrapolací metody v Matlabu a FSL. V obrázku 5.1 lze vidět, že po umístění referenčního bodu na stejné místo v každém obraze jsme v sagitálním a frontálním směru nepozorovali výrazné změny, ale v transverzálním směru lze vidět misregistraci o jeden voxel mezi svazky nervových vláken, tato misregistrace je nejvíce viditelná u FA obrazu zkonstruovaného pomocí Matlabu.

Přesnost registrace jsme ověřili porovnáním transformačních matic. Výsledky jednotlivých transformací jsme uvedli v tabulce 5.1. Celkově lze vidět, že mezi obrazy nedošlo k výrazným změnám, jen u metod FSL a Matlab (CHARMED) došlo ve směru osy X k posunu o 0,1 mm, což je při velikosti 2 mm na voxel malá hodnota.

Tab. 5.1: Výstupní hodnoty transformací

FSL	Osa:X	Osa:Y	Osa:Z
Rotace (stupeň)	0,034	0,024	0
Posun (mm)	0,093	0,043	-0,004
Změna měřítka (%)	0,01	0,01	0,01
Zkosení (%)	0,0001	-0,0006	0,0001
Matlab (CHARMED)	Osa:X	Osa:Y	Osa:Z
Rotace (stupeň)	0	0	0
Posun (mm)	0,102	-0,006	0,021
Změna měřítka (%)	0,01	0,01	0,01
Zkosení (%)	-0,0002	-0,0004	-0,0001
FSL (CHARMED-ref)	Osa:X	Osa:Y	Osa:Z
Rotace (stupeň)	0,032	0	0,057
Posun (mm)	-0,039	-0,024	-0,036
Změna měřítka (%)	0	0,01	0,01
Zkosení (%)	0,0002	0	0,001

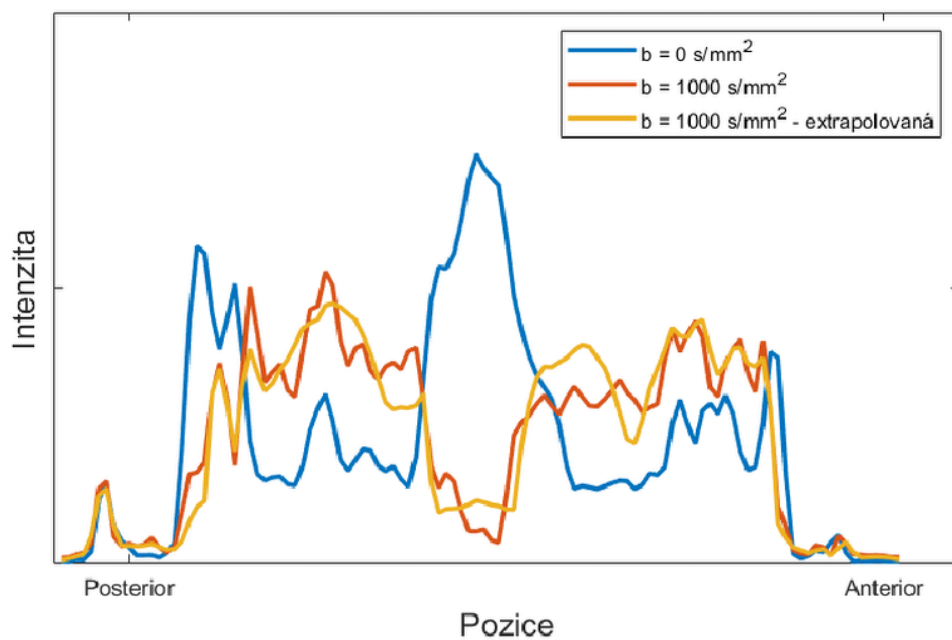



Obr. 5.1: Porovnání jednotlivých oblastí mezi FA obrazy. První sloupec označený jako A obsahuje FA obraz vzniklý běžnou metodou z nízkých b-hodnot a druhý sloupec B tu samou metodu za použití vysokých b-hodnot. Sloupec C a D obsahuje FA obrazy z vysokých b-hodnot s využitím extrapoláční metody. Sloupec C zobrazuje provedení v FSL a sloupec D v Matlabu.

## 5.2 Porovnání intenzit

Pro srovnání intenzit mezi difúzními obrázky jsme provedli výběr řezu znázorněného v horní části 5.2. Mezi vybranými obrázky je zvolen snímek bez difúzního vážení


a dva difúzně vážené snímky s  $b$ -hodnotou  $1000 \text{ s mm}^{-2}$ . První difúzní snímek je originálně nasnímaný a druhý je vytvořen pomocí extrapolace. Na grafu pak lze vidět srovnání intenzity signálu mezi jednotlivými pozicemi v řezu. Tento řez je zvolen tak, aby obsahoval oblast korpus kalosum, ve které dochází k vysoké anizotropní difúzi. Můžeme sledovat jak v případě difúze se prohodí jednotlivé intenzity oproti snímku bez difúzního vážení, největší ztrátu intenzity lze sledovat už ve zmíněné oblasti korpus kalosum. Při srovnání difúzně vážených snímků lze vidět jak extrapolovaná reference věrohodně kopíruje intenzitu snímku s  $b$ -hodnotou  $1000 \text{ s mm}^{-2}$ .



Obr. 5.2: Srovnání intenzit mezi snímky s  $b$ -hodnotou  $0, 1000 \text{ s mm}^{-2}$  a extrapolovaným snímkem

### 5.3 Vyhodnocení podle šachovnice

Pomocí šachovnice podobrazů jsme zobrazili rozdíly mezi obrázky před registrací a po ní. Šachovnice byla provedena pomocí implementovaného modulu v 3D Sliceru, kde světlé čtverce zobrazují referenční snímek a tmavé transformovaný. Na přiloženém obrázku 5.3 jsou zobrazeny celkem čtyři šachovnice z nichž první reprezentuje srovnání reference s transformovaným obrazem před registrací, na kterém lze vidět nesrovnalosti mezi jednotlivými strukturami mozku včetně okraje lebky, tak i vliv artefaktů v anteriorní části mozku. Zbylé tři šachovnice reprezentují transformovaný obraz po úpravě jednotlivými registračními procesy. U všech třech registrací lze vidět podobný výsledek, kde zmizely artefakty a jednotlivé struktury na sebe lépe pasují. Celkově je tahle metoda pro naše data nepraktická a slouží spíš jako ukázka překrytí dat s různou difúzní vahou.



Obr. 5.3: Vlevo nahoře výsledná šachovnice před registrací v pravo po klasické registraci v FSL, dole vlevo registrace CHARMED-FSL a vpravo CHARMED v Matlabu.

## 6 Závěr

V této bakalářské práci se zabýváme koregistrací difúzně vážených MRI dat. V první části uvádíme, co to koregistrace znamená a popisujeme vznik difúzně vážených obrazů. Dále uvádíme charakteristiku b-hodnoty a její vliv na výsledný kontrast. Mimo to uvádíme, jaké postupy je třeba provést, abychom dosáhli úspěšné koregistrace. Mezi tyto postupy patří hlavně vyhlazování, interpolace, transformace a optimalizace.

Druhá část se věnuje softwarovým nástrojům, které se danou problematikou zabývají a to jak předzpracováním, samotnou koregistrací a nebo jejím vyhodnocením. Koregistrace zde slouží jako nástroj pro korekci artefaktů způsobených pohybem zkoumaného objektu, susceptibilitou a vířivými proudy.

Následující kapitola obsahuje popis metod pro vyhodnocení kvality koregistrací s jejich ukázkami. Mezi uvedené metody jsme zařadili porovnání vybraných oblastí vůči referenčnímu bodu, rozdíl mezi transformačními parametry, srovnání intenzit vybraného řezu, histogram, a šachovnici.

Praktické části se věnujeme ve čtvrté kapitole. Uvádíme typ sekvence nasnímaných dat a jejich charakteristiky, jako jsou velikost voxelů, formát NIfTI, b-hodnota a prostorové rozlišení. Dále zde uvádíme použité programy a postup zpracování našich difúzních dat. V práci se zabýváme klasickou metodou koregistrace, kdy jsou první obrazy koregistrovány vůči referenci bez difúzního vážení a následně jsou koregistrovány vůči průměrným snímkům pro každou b-hodnotu. Dále rozebíráme metodu, která využívá extrapolování reference na základě CHARMED modelu, tento postup je realizován pomocí Matlab toolboxu Multidimensional diffusion MRI. Extrapolované reference jsme využili i pro koregistraci v FSL místo průměrných obrazů. Ze zaregistrovaných dat jsme vytvořili obrazy frakční anizotropie (FA) složené z dat s vysokou a nízkou mírou difúzního vážení.

Poslední kapitola se věnovala vyhodnocení koregistrací. Jejich kvalitu jsme klasifikovali pomocí koregistrace FA obrazů, kde z výsledných transformací lze kvantifikovat kvalitu registrace. Pomocí vizuálních metod jako je porovnání jednotlivých oblastí mezi zvolenými obrazy jsme mohli subjektivně určit úspěšnost registrace.

Ověřili jsme, že registrace u všech použitých metod proběhla úspěšně bez viditelných nesrovnalostí. Potvrdily to výsledky koregistrace FA map s různými b-hodnotami (transformační matice). V našem případě se neprokázalo, že by CHARMED model vůči standartnímu preprocessingu pomocí nástroje fsl eddy dosahoval lepších výsledků. Je však nutné vzít v potaz, že naše b-hodnoty jsou 700, 1000 a  $2300 \text{ s mm}^{-2}$ , v některých studiích jsou používány b-hodnoty dosahujících  $3000 \text{ s mm}^{-2}$ , ale i  $5000 \text{ s mm}^{-2}$ . [27], [28] V takovém případě by CHARMED model, který věrohodněji simuluje realitu mohl mít výraznější vliv a stojí za další výzkum.

## Literatura

- [1] DWI b-Value. D. ELSTER, Allen. *MRIquestions* [online][cit. 2019-12-28]. Dostupné z: <http://mriquestions.com/what-is-the-b-value.html>
- [2] Schaefer PW, Grant PE, Gonzalez RG. *Diffusion-weighted MR imaging of the brain*. Radiology. 2000 Nov;217(2):331-45. Dostupné z: <https://doi.org/10.1148/radiology.217.2.r00nv24331> PMID: 11058626.
- [3] STEVEN, Andrew J., Jiachen ZHUO a Elias R MELHEM. *Diffusion Kurtosis Imaging: An Emerging Technique for Evaluating the Microstructural Environment of the Brain*. American journal of roentgenology. Am Roentgen Ray Soc, 2014, 1(202), 26-33. Dostupné z: <https://doi.org/10.2214/AJR.13.11365>
- [4] HAGMANN, Patric, Lisa JONASSON, Philippe MAEDER, Jean-Philippe THIRAN, Van J. WEDEEN a Reto MEULI. *Understanding diffusion MR imaging techniques: from scalar diffusion-weighted imaging to diffusion tensor imaging and beyond*. RadioGraphics [online]. ISSN 0271-5333. Dostupné z: <https://doi.org/10.1148/rg.26si065510>
- [5] Ben-Amitay S, Jones DK, Assaf Y. *Motion correction and registration of high b-value diffusion weighted images* Magn Reson Med. 2012; 67: 1694–1702 Dostupné z: <https://doi.org/10.1002/mrm.23186>
- [6] ANDERSSON, Jesper L.R., Stefan SKARE a John ASHBURNER. *How to correct susceptibility distortions in spin-echo echo-planar images: application to diffusion tensor imaging*. NeuroImage [online]. 2003, 20(2), 870-888 [cit. 2021-5-4]. ISSN 10538119. Dostupné z URL: [https://doi.org/10.1016/S1053-8119\(03\)00336-7](https://doi.org/10.1016/S1053-8119(03)00336-7)
- [7] ASHBURNER, John a Karl J. FRISTON. *Rigid Body Registration*. Human Brain Function [online]. 2004, 1(Second Edition), 1-1144 [cit. 2018-11-18]. DOI: 10.1016/B978-012372560-8/50004-8. ISSN 978-0-12-264841-0. Dostupné z: <https://www.fil.ion.ucl.ac.uk/spm/doc/books/hbf2/pdfs/Ch2.pdf>
- [8] Eddy Currents. D. ELSTER, Allen. *MRIquestions* [online][cit. 2021-5-4]. Dostupné z: <http://mriquestions.com/eddy-current-problems.html>
- [9] ASHBURNER, John, Karl J. FRISTON, R.S.J. FRACKOWIAK, K.J. FRISTON, C. FRITH, R. DOLAN a J.C. MAZZIOTTA. *Spatial transformation of images*. Human Brain Function [online]. 1. USA: Academic Press USA, 1997, s. 1-36 [cit. 2018-11-18]. Dostupné z: <https://www.fil.ion.ucl.ac.uk/spm/doc/books/hbf1/Ch2.pdf>



- [10] ITK contributors *Insight Segmentation and Registration Toolkit* [online]. [cit. 2018-12-28]. Dostupné z: <https://itk.org/>
- [11] CHUNG, Moo K. *Gaussian Kernel Smoothing*. Statistical and Computational Methods in Brain Image Analysis. [online]. CRC Press, 2013 [cit. 2019-12-28]. ISBN 9780429094323 Dostupné z URL: <https://doi.org/10.1201/b15056>
- [12] ASHBURNER, J a K FRISTON. *Multimodal Image Coregistration and Partitioning—A Unified Framework*. NeuroImage [online]. 1997, 6(3), 209-217 [cit. 2021-5-28]. ISSN 10538119. Dostupné z: <https://doi.org/10.1006/nimg.1997.0290>
- [13] JENKINSON, M. *Improved Optimization for the Robust and Accurate Linear Registration and Motion Correction of Brain Images*. NeuroImage [online]. 17(2), 825-841 [cit. 2019-12-28]. ISSN 10538119. Dostupné z: [https://doi.org/10.1016/S1053-8119\(02\)91132-8](https://doi.org/10.1016/S1053-8119(02)91132-8)
- [14] MAULIK, Ujjwal a Sanghamitra BANDYOPADHYAY. *Genetic algorithm-based clustering technique*. Pattern Recognition [online]. 2000, 33(9), 1455-1465 [cit. 2021-3-2]. ISSN 00313203. Dostupné z: [https://doi.org/10.1016/S0031-3203\(99\)00137-5](https://doi.org/10.1016/S0031-3203(99)00137-5)
- [15] HONGYING ZHANG, XIAOZHOU ZHOU, JIZHOU SUN a JIAWAN ZHANG. *A Novel Medical Image Registration Method Based on Mutual Information and Genetic Algorithm*. In: International Conference on Computer Graphics, Imaging and Visualization (CGIV'05) [online]. IEEE, 2005, s. 221-226 [cit. 2021-3-2]. ISBN 0-7695-2392-7. Dostupné z: <https://doi.org/10.1109/CGIV.2005.8>
- [16] ROBINSON, J. a Y. RAHMAT-SAMII. *Particle Swarm Optimization in Electromagnetics*. IEEE Transactions on Antennas and Propagation [online]. 2004, 52(2), 397-407 [cit. 2021-6-3]. ISSN 0018-926X. Dostupné z: <https://doi.org/10.1109/TAP.2004.823969>
- [17] BROWN, Lisa Gottesfeld. *A survey of image registration techniques*. ACM Computing Surveys [online]. 1992, 24(4), 325-376 [cit. 2021-5-4]. ISSN 0360-0300. Dostupné z: <https://doi.org/10.1145/146370.146374>
- [18] AFNI contributors. *Analysis of Functional NeuroImages*. [online]. [cit. 2018-12-28]. Dostupné z: <https://afni.nimh.nih.gov/>
- [19] SPM contributors *Statistical Parametric Mapping* [online]. [cit. 2018-12-28]. Dostupné z: <https://www.fil.ion.ucl.ac.uk/spm/>

- [20] FSL contributors *FMRIB Software Library* [online]. [cit. 2018-12-28]. Dostupné z: <https://fsl.fmrib.ox.ac.uk/fsl/fslwiki/FSL>
- [21] KLEIN, S., M. STARING, K. MURPHY, M.A. VIERGEVER a J. PLUIM. *Elastix: A Toolbox for Intensity-Based Medical Image Registration*. IEEE Transactions on Medical Imaging [online]. 2010, 29(1), 196-205 [cit. 2021-4-21]. ISSN 0278-0062. Dostupné z: <https://doi.org/10.1109/TMI.2009.2035616>
- [22] SHAMONIN, Denis. *Fast parallel image registration on CPU and GPU for diagnostic classification of Alzheimer's disease*. Frontiers in Neuroinformatics [online]. 2013, 7 [cit. 2021-4-21]. ISSN 16625196. Dostupné z: <https://doi.org/10.3389/fninf.2013.00050>
- [23] FEDOROV, Andriy, R. BEICHEL, J. KALPATHY-CRAMER a J. FINET. *3D Slicer as an Image Computing Platform for the Quantitative Imaging Network*. [online]. 2012 [cit. 2019-03-20]. Dostupné z: <https://www.slicer.org/>
- [24] NILSSON, Markus, Filip SZCZEPANKIEWICZ, Danielle VAN WESTEN, Oskar HANSSON a Mara CERCIGNANI. *Extrapolation-Based References Improve Motion and Eddy-Current Correction of High B-Value DWI Data: Application in Parkinson's Disease Dementia*. PLOS ONE [online]. 2015, 10(11) [cit. 2021-5-28]. ISSN 1932-6203. Dostupné z: <https://doi.org/10.1371/journal.pone.0141825>
- [25] RAJAGOPALAN, Venkateswaran, Zhiguo JIANG, Guang H YUE, Jelena Stojanovic RADIC, Erik P PIORO, Glenn R WYLIE a Abhijit DAS. *AA Basic Introduction to Diffusion Tensor Imaging Mathematics and Image Processing Steps*. Brain Disorders and Therapy [online]. 2017, 06(02) [cit. 2021-5-25]. ISSN 2168975X. Dostupné z: <https://doi.org/10.4172/2168-975X.1000229>
- [26] Markus Nilsson, Filip Szczepankiewicz, Björn Lampinen, André Ahlgren, João P. de Almeida Martins, Samo Lasic, Carl-Fredrik Westin, and Daniel Topgaard. *An open-source framework for analysis of multidimensional diffusion MRI data implemented in MATLAB*. Proc. Intl. Soc. Mag. Reson. Med. (26), Paris, France, 2018. Dostupné z: <http://archive.ismrm.org/2018/5355.html>
- [27] LETTAU, Michael a Mona LAIBLE. *3-T high-b-value diffusion-weighted MR imaging of hyperacute ischemic stroke in the vertebrobasilar territory*. Journal of Neuroradiology [online]. 2012, 39(4), 243-253 [cit. 2021-6-1]. ISSN 01509861. Dostupné z: <https://doi.org/10.1016/j.neurad.2011.09.005>
- [28] TOURNIER, J.-Donald, Fernando CALAMANTE a Alan CONNELLY. *Determination of the appropriate b value and number of gradient directions for*

*high-angular-resolution diffusion-weighted imaging*. NMR in Biomedicine [online]. 2013, 26(12), 1775-1786 [cit. 2021-6-1]. ISSN 09523480. Dostupné z: <https://doi.org/10.1002/nbm.3017>

## Seznam symbolů, veličin a zkratek

<b>AFNI</b>	Analysis of Functional NeuroImages, Analýza funkčních obrazů mozku
<b>CT</b>	computed tomography, výpočetní tomografie
<b>DWI</b>	Diffusion weighted imaging, difusně vážené zobrazování
<b>DTI</b>	Diffusion tensor imaging
<b>DKI</b>	Diffusion kurtosis imaging
<b>EEG</b>	Electroencephalography, elektroencefalografie
<b>EMG</b>	electromyography, elektromyografie
<b>FSL</b>	FMRIB Software Library
<b>fMRI</b>	functional Magnetic Resonance Imaging
<b>ITK</b>	Insight Segmentation and Registration Toolkit
<b>LS</b>	least squares, nejmenší čtverec
<b>MI</b>	mutual information, vzájemná informace
<b>NMI</b>	normalised mutual information, vzájemná informace
<b>MRI</b>	magnetic resonance imaging, magnetická rezonance
<b>NC</b>	normalised correlation, normalizovaná korelace
<b>CR</b>	correlation ratio, korelační poměr
<b>PET</b>	positron emission tomography, pozitronová emisní tomografie
<b>SNR</b>	Signal to noise ratio, poměr signál šum
<b>SPECT</b>	Single-Photon Emission Computed Tomography, Jednofotonová emisní výpočetní tomografie
<b>SPM</b>	Statistical parametric mapping
<b>FLIRT</b>	FMRIB's Linear Image Registration Tool
<b>AP</b>	anterior-posterior
<b>PA</b>	posterior-anterior
<b>FA</b>	frakční anizotropie

# Seznam příloh

A Elastix parametry

45

## A Elastix parametry

- (FixedInternalImagePixelType "float")
- (FixedImageDimension 3)
- (MovingInternalImagePixelType "float")
- (MovingImageDimension 3)
- (Registration "MultiResolutionRegistration")
- (FixedImagePyramid "FixedRecursiveImagePyramid")
- (MovingImagePyramid "MovingRecursiveImagePyramid")
- (Interpolator "BSplineInterpolator")
- (Optimizer "AdaptiveStochasticGradientDescent")
- (ResampleInterpolator "FinalBSplineInterpolator")
- (Resampler "DefaultResampler")
- (Transform "AffineDTITransform")
- (Metric "AdvancedMattesMutualInformation")
- (ErodeMask "false")
- (HowToCombineTransforms "Compose")
- (AutomaticTransformInitialization "false")
- (AutomaticScalesEstimation "true")
- (DefaultPixelValue 0 )
- (WriteResultImage "true")
- (ResultImagePixelType "float")
- (ResultImageFormat "nii")
- (CompressResultImage "false")
- (NumberOfResolutions 1 )
- (MaximumNumberOfIterations 200 )
- (NumberOfHistogramBins 32 )
- (ImagePyramicSchedule 1.000000 1.000000 1.000000 )
- (ImageSampler "RandomCoordinate")
- (NewSamplesEveryIteration "true")
- (NumberOfSpatialSamples 8192 )
- (BSplineInterpolationOrder 1 )
- (FinalBSplineInterpolationOrder 3 )